

УДК 004.7

DOI: 10.31673/2786-8362.2026.016712

Швец Д.М.; Трейтяк В.В., к.т.н.

МЕТОД ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ ПЕРЕДАЧІ МЕРЕЖ WI-FI ТА LTE-U З ВИКОРИСТАННЯМ ML-АЛГОРИТМІВ

Shvets D.M., Treitiak V.V. Method for improving the transmission efficiency of Wi-Fi and LTE-U networks using ML algorithms. The article considers the problem of adaptive LTE access in unlicensed spectrum, taking into account coexistence with Wi-Fi, regulatory restrictions, and limited resources of edge devices. A working architecture is proposed that combines lightweight convolutional neural networks for radio signal classification and detection, recurrent models for short-term channel load prediction, and reinforcement learning algorithms for channel selection, TXOP, and shutdown patterns. The proposed approach optimizes LTE throughput while maintaining fairness to Wi-Fi, minimizing overhead and raw data transmission through lightweight models and federated strategies. Evaluation criteria are provided, experimental scenarios are described, and advantages over static methods are justified. The proposed approach combines observation, prediction, and control methods into a single working architecture that provides a practical opportunity to improve LTE spectral efficiency in the unlicensed band while maintaining fairness criteria with respect to Wi-Fi.

Keywords: Wi-Fi, LTE, unlicensed spectrum, CNN, machine learning, RL-LSTM, Q-learning

Швец Д.М., Трейтяк В.В. Метод підвищення ефективності передачі мереж Wi-Fi та LTE-U з використанням ML-алгоритмів. У статті розглядається задача адаптивного доступу LTE у неліцензованому спектрі з урахуванням співіснування з Wi-Fi, регуляторних обмежень та обмежених ресурсів краєвих пристроїв. Пропонується робоча архітектура, що поєднує легкі згорткові нейронні мережі для класифікації та детекції радіосигналів, рекурентні моделі для короткострокового прогнозування завантаження каналу і алгоритми підкріплювального навчання для прийняття рішень про вибір каналу, TXOP та шаблони вимкнення. Запропонований підхід оптимізує пропускну здатність LTE за умови збереження справедливості щодо Wi-Fi, мінімізуючи накладні витрати та передачу сирих даних за рахунок легких моделей і федеративних стратегій. Наведено критерії оцінки, описано експериментальні сценарії та обґрунтовано переваги над статичними методами. Запропонований підхід комбінує методи спостереження, прогнозування та управління в єдину робочу архітектуру, яка забезпечує практичну можливість підвищення спектральної ефективності LTE у неліцензованому діапазоні при одночасному дотриманні критеріїв справедливості щодо Wi-Fi.

Ключові слова: Wi-Fi, LTE, неліцензований спектр, CNN, машинне навчання, RL-LSTM, Q-навчання

Вступ

Різке зростання мобільного трафіку та бурхливий розвиток бездротових сервісів призвели до того, що традиційні ліцензовані частотні ресурси стають дедалі дефіцитнішими. Як наслідок, оператори та виробники мережевого обладнання активно вдаються до використання неліцензованого спектру (зокрема діапазону 5 ГГц) для розвантаження мережі, впровадження малих стільників і надання нових сервісів з низькою затримкою. Однак експлуатація технологій LTE в неліцензованому спектрі зустрічає суттєву перешкоду – необхідність ефективно співіснувати з уже розгорнутими системами Wi-Fi та іншими технологіями, що діють у тій самій смузі.

Проблема співіснування має кілька вимірів. По-перше, існує технічна складність у надійній ідентифікації радіоджерел та розпізнаванні типу трафіку в умовах шуму і частих змін каналів. По-друге, навіть за умови точного виявлення, необхідно приймати рішення про доступ до каналу (вибір частотного каналу, тривалості передачі (TXOP) та режимів вимкнення підкадрів) так, щоб максимізувати пропускну здатність LTE-сервісу, не руйнуючи при цьому якість обслуговування Wi-Fi. По-третє, регуляторні вимоги та критерії «справедливості» часто накладають додаткові обмеження (наприклад, LBT, обмеження TXOP), які потрібно враховувати в режимі реального часу. Крім того, сучасні підходи до оптимізації доступу в спектрі стикаються з практичними обмеженнями розгортання. Багато рішень, що показують високу ефективність у симуляціях, вимагають значних обчислювальних ресурсів або

централізованої телеметрії, що погано сумісно з архітектурою Edge-обчислень та вимогами приватності (непередача сирих I/Q даних). У реальних мережах рішення мають бути легкими для виконання на периферійних пристроях, адаптивними до різноманітних сценаріїв (різна щільність вузлів, SNR, присутність прихованих терміналів) і стійкими до невизначеності в спостереженнях.

У відповідь на ці виклики у сучасних дослідженнях зростає інтерес до комбінації методів машинного навчання: легкі згорткові нейронні мережі для класифікації сигналів і оцінки невизначеності, рекурентні моделі для прогнозування зайнятості каналу і алгоритми підкріплювального навчання (включно з багатоагентними підходами) для прийняття політик доступу до спектру. Такі рішення обіцяють підвищити ефективність спектрального використання при дотриманні вимог справедливості й регуляторних обмежень, але вимагають ретельної інтеграції та тестування в реалістичних умовах.

Аналіз останніх досліджень. В [1] зроблено огляд методів співіснування LTE в режимі License Assisted Access (LAA) і Wi-Fi у діапазоні 5 ГГц, детально розглянуто LBT-підходи, запропоновано справедливу схему з TXOP для eNB і проаналізовано продуктивність різних LBT-рішень за допомогою марковської моделі. В [2] запропоновано динамічне оновлення TXOP на основі HARQ для LTE-LAA, що підвищує справедливість і сумарну пропускну здатність у співіснуванні з Wi-Fi порівняно зі статичним TXOP. В [3] запропоновано ML-підхід, який за енергетичними вимірюваннями під час LTE-U OFF визначає число спільних каналів Wi-Fi BSS без декодування пакетів з $\approx 99\%$ точністю. В [4] запропоновано метод контролю бекофу та розподілу пакетів для співіснування LTE-U і Wi-Fi через новий інтерфейс у гетерогенній Cloud-RAN (H-CRAN), наведено огляд ключових технологій 5G і їхніх наслідків. В [5] показано, що LSTM найкраще моделює часові тренди та піки, а Aux-LSTM підвищує надійність прогнозів, одночасно зменшуючи ризики приватності. В [6] запропоновано адаптивну LBT-схему mLTE-U зі змінним TXOP та періодом вимикання передавача, підсилене Q-навчання для автономного підбору комбінацій TXOP/вимикання задля справедливого співіснування з Wi-Fi. В [7] запропоновано DRL-фреймворк для динамічного регулювання часу передачі між 5G NR-V2X і Wi-Fi 6E; його реалізація в симуляціях Network Simulator-3 (ns-3), інтегрованих із OpenAI Gym, показала $\approx 24\%$ і $\approx 23\%$ зростання середніх швидкостей для VUE і WUE відповідно, причому mode-1 потребує більше спектру. В [8] математично змодельовано вплив періодів передавання/пауз LTE-U на продуктивність Wi-Fi, ввели метрику «справедливості» (різниця між втратою продуктивності Wi-Fi та долею часу LTE-U), розглянули випадки сильних/слабких завад (поріг -62 дБм) і верифікували висновки методом Монте-Карло. В [9] запропоновано Q-навчання та DQN для вибору оптимальної технології зв'язку (BLE/LTE/Wi-Fi/LoRa) у БПЛА-мережі з метою мінімізації енергоспоживання та затримки, порівняно з базовими схемами. В [10] запропоновано централізовану та децентралізовану стратегії для пошуку рівноваги Неша в гетерогенних багатоагентних системах, а чисельні експерименти показують успішне досягнення рівноваги зі значним зменшенням комунікаційних витрат. В [11] представлено короткий огляд можливостей федеративного підкріплювального навчання (FRL) для восьми ключових функцій Wi-Fi із кейс-дослідженням каналної активації в MLO, що демонструє потенціал FRL для децентралізованої, приватної та адаптивної координації в мережах Wi-Fi 7. В [12] розроблено аналітичну модель для Cat 4 LAA (3GPP Release 13), оптимізовано сумарну пропускну здатність LTE-LAA і Wi-Fi за обмеженням справедливості методом «branch-and-bound» та алгоритмами підкріплювального навчання (кооперативний і некооперативний), причому RL значно покращує пропускну здатність, а кооперативний підхід наближається до аналітичної межі. В [13] запропоновано ансамблевий метод прогнозування CQI на основі RSRP/RSRQ/RSSI/SNR, який на публічних LTE-даних перевершує окремі моделі (MAE = 0,66, $R^2 = 0,93$) і має затримку 0,052 мс/зразок, сумісну з режимом реального часу. В [14] запропоновано мета-навчальний онлайн-алгоритм керування для послідовності N подібних лінійних задач, а експерименти підтверджують його перевагу.

Постановка завдання. У неліцензованих діапазонах (зокрема 5 ГГц) технології LTE (LTE-U/LAA/mLTE-U) повинні співіснувати з Wi-Fi так, щоб забезпечити задовільну пропускну здатність для LTE-системи при одночасному дотриманні вимог «справедливості» щодо Wi-Fi, регуляторних обмежень і обмежених обчислювальних ресурсів на краю мережі. Для цього необхідні методи: (i) надійної ідентифікації й оцінки активності радіопередавань (CNN на I/Q або спектрограмах), (ii) прогнозування майбутньої активності каналу (LSTM/RL-LSTM), та (iii) адаптивного управління часовими вікнами передач (TXOP), вибору каналів і шаблонів вимкнення передавача за допомогою алгоритмів підкріплювального та багатоагентного навчання.

Метою роботи є розробка підходу до адаптивного доступу LTE у неліцензованому спектрі, який поєднує онлайн-детекцію та класифікацію ефірної активності, короткострокове прогнозування завантаження каналу і прийняття рішень про використання ресурсу за допомогою алгоритмів підкріплювального навчання, який в реальному часі максимально збільшує корисну пропускну здатність LTE в неліцензованому спектрі, за умови дотримання критеріїв справедливості щодо Wi-Fi та обмежень регуляторного характеру.

Виклад основного матеріалу дослідження

Існує сукупність методів на основі нейронних мереж та машинного навчання для підвищення якості зв'язку LTE, що працює в неліцензованому спектрі та співіснує одночасно з іншими технологіями (зокрема Wi-Fi). Такі підходи охоплюють автоматичну ідентифікацію та класифікацію радіосигналів, прогнозування завантаження та доступності каналу, адаптивний вибір каналів і стратегій вимкнення передавача та TXOP (Transmission Opportunity – Можливість передачі), а також розподілені ігрові та багатоагентні схеми навчання – усі вони формулюються з урахуванням вимог до справедливості та обмежень обчислювальних ресурсів на базових станціях. Практичні результати і конфігураційні рекомендації спираються на емпіричні дослідження, у тому числі на роботу з CNN для розпізнавання LTE/Wi-Fi, RL-LSTM (Reinforcement Learning with Long Short-Term Memory – Навчання з підкріпленням з довгою короткотривалою пам'яттю) для проактивного управління ресурсами та Q-learning для спільного вибору каналу/підкадрів.

Класифікація та детекція передач (Signature Recognition). Для того, щоб коректно розподіляти доступ до каналу в умовах сумісної роботи різних технологій, критично необхідна надійна реальна ідентифікація активних передавачів і характеру їхніх фреймів (LTE та Wi-Fi, кількість одночасних передавань, ефект прихованого вузла). Згорткові нейронні мережі (Convolutional Neural Network – CNN), навчені на сирих I/Q вибірках або на спектральних представленнях таких як FFT (Fast Fourier Transform), демонструють високу точність класифікації таких станів і можуть працювати в режимі реального часу, забезпечуючи вхідні ознаки для адаптивних алгоритмів доступу до середовища. Практична реалізація показала, що вибір представлення сигналу (I/Q проти FFT) суттєво впливає на точність, а навчання на COTS-обладнанні дозволяє отримати робочі моделі.

Сигнали захоплюються SDR/COTS приймачами у вигляді сирих I/Q-вбірок з фіксованою частотою дискретизації (наприклад, 1-20 MS/с залежно від ширини каналу). Обов'язкові кроки препроцесінгу: AGC-калібрування (Automatic Gain Control – Автоматичне регулювання підсилення), або нормалізація амплітуди, зміщення частоти, фільтрація каналу (екранне згладжування) та сегментація у вікна фіксованої довжини з перекриттям (10-100 мс з 50% накладанням для гармонізації затримки до точності). Для перетворень частотної області використовують короткочасове FFT; для тимчасових моделей залишаються 1D-послідовності I/Q або комплексні матричні представлення (реальна/уявна частина). Гібридні архітектури часто дають кращу роботу в широкому діапазоні SNR. Набір даних повинен відображати реальні умови: SNR від -5 до +30 дБ, різні частотні зсуви (до ± 10 кГц), багатошляховий ввід-вивід (модель EPA/ETU), різні щільності Wi-Fi/LTE вузлів, імітації прихованого вузла. Для підвищення точності вибірки додається AWGN, частотні/часові зміщення, імпульсні перешкоди, випадкова квантизація амплітуди.

Вихід CNN передається в контролер як набір ознак: класифікація технології, оцінка числа активних потоків, моментні передбачення ефірного часу/енергії, та рівень впевненості. Контролер має використовувати ці ознаки в правилі прийняття рішень (наприклад, RL-контролер або евристики): при виявленні високої активності Wi-Fi – знижувати терміни передавання/паузи або обирати патерн вимикання передавача; при виявленні низької активності – агресивніше використовувати LTE-передавання.

Проактивне прогнозування та управління ресурсами (LSTM/RL-LSTM). Замість реактивної політики «виявлення та уникнення» доцільним є проактивне планування: моделі LSTM/RL-LSTM прогнозують майбутню активність WLAN, завантаження UE та доступність каналів на горизонті часу, після чого оптимізують вибір каналів, агрегацію компонентних несучих і дробове використання спектру. Така схема дає можливість згладжувати піки навантаження, підвищувати загальну пропускну здатність і забезпечувати довгострокову рівноправність доступу між технологіями, RL-LSTM приносить суттєві прирости відносно реактивного підходу. В підході розглядається дискретний час $t=0,1,\dots$ з кроком Δt . Кожен агент (SBS) оперує над множиною каналів $C=\{1,\dots,C\}$. Спостереження (на момент t):

$$x_{t,c}=[\text{RSSI}_{t,c}, \text{energy}_{t,c}, \text{spec}_{t,c}, \text{MAC_stats}_{t,c}, \dots] \text{ для кожного } c.$$

Об'єкт прогнозування (горизонт H):

$$B_{t+h,c}=\text{Pr}(\text{канал зайнятий в } t+h|X_t) \\ u_{t+h,c}=\text{E}[\text{airtime}_{t+h,c}|X_t], h=1\dots H.$$

Дії агента в слоті t :

$$a_t=(c_t, \alpha_{t,c}, s_t),$$

де c_t – обраний канал, $\alpha_{t,c} \in [0,1]$ – частка доступу/роботи або число підкадрів/вимикань, s_t – паттерн вимикань/підкадрів.

Метою методу є максимізація довгострокової корисності LTE з урахуванням обмежень справедливості та регуляторних вимог:

$$\min_{\pi} \text{E}_{\pi} \left[\sum_{t=0}^{\infty} \gamma^t r_t \right] \text{ за умови } \text{E}_{\pi} [g_i] \leq c_i \forall i,$$

де r_t – винагорода (пропускну здатність – покарання), g_i – обмеження (наприклад, ефірного часу Wi-Fi), γ – дисконт. Система складається з трьох основних модулів що поєднують переваги контрольованого прогнозування та навчання через винагороду:

- 1) Препроцесінг і сенсори – SDR/COTS збір I/Q, FFT, MAC лічильники та формування тимчасових вікон довжини W .
- 2) LSTM-прогностор – LSTM/GRU виду Seq2Seq або «багато-до-багатьох», що видає $b_{t+1:t+H}$, $u_{t+1:t+H}$ і, за бажанням, їхню невпевненість σ .
- 3) RL-контролер (політики/значень) – DQN/PPO (Prioritized Experience Replay – Відтворення пріоритетного досвіду), що на вході приймає розширений стан $s_t=[x_t, h_t^{\text{LSTM}}, b_{t+1:t+H}, u_{t+1:t+H}, \sigma]$ і повертає дію a_t .

Підкріплювальне навчання для вибору каналу та підкадрів (Q-learning/DRL). У задачах, де рішення приймаються локально на AP/SBS без повної інформації про Wi-Fi-вузли, ефективні алгоритми на основі Q-learning або глибокого підкріплення (Deep Q Network – DQN) дозволяють навчитись політиці вибору каналу та числа підкадрів так, щоб мінімізувати колізії та втрати пакетових передань і при цьому зберегти цільову справедливість. Додавання штрафу за часті перемикання каналу (Channel Switching Penalty) знижує нестабільність конфігурації і зменшує накладні витрати на перепідключення. Емпіричні дані свідчать про покращення показників справедливості і зниження втрат пакетів порівняно зі статичними схемами. В цьому підході класичне оновлення Q-значення для дискретного MDP формулюється як:

$$Q(s_t, a_t) = Q(s_t, a_t) + \alpha \left(r_{t+1} + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t) \right),$$

де α – швидкість навчання, γ – дисконт-коефіцієнт. Перевагами табличного підходу є простота та прозорість, проте недоліком є експоненціальний ріст таблиці при збільшенні

розрядності стану, що є неприйнятним в високорозмірних спостереженнях (I/Q, особливості спектру). В цьому випадку табличний Q-learning доцільно замінити апроксимацією $Q(s, a; \theta)$ – DQN:

$$L(\theta) = \mathbb{E}_{(s,a,r,s') \sim D} \left[\left(r + \gamma \max_{a'} Q(s', a'; \theta^-) - Q(s, a; \theta^-) \right)^2 \right],$$

де θ – старі параметри цільової мережі. Для підвищення стабільності та зменшення переоцінки застосовується подвійний DQN $\max_{a'} Q(s', a'; \theta)$, PPO для семплювання важливих переходів та дуельні архітектури при різних впливах вибору каналу або підкадру. Для збільшення стабільності і зменшення накладних витрат із-за перереєстрації та RACH-процесів, до винагороди додається терм за перемикання:

$$r_t = r_t - \eta \cdot 1\{c_t \neq c_{t-1}\} - \zeta \cdot 1\{s_t \neq s_{t-1}\},$$

де $\eta, \zeta \geq 0$ – коефіцієнти перемикання-ціни (Switch-Cost). Альтернативно застосовується м'яка регуляризація через L2-відхилення від попередніх дій:

$$\text{SwitchCost}_t = \eta_c \cdot 1\{c_t \neq c_{t-1}\} + \eta_s \cdot |s_t - s_{t-1}|.$$

Налаштування цих коефіцієнтів дозволяє балансувати між адаптивністю і стабільністю конфігурації.

Адаптивні чергування передавання/пауз, стратегії вимикання передавача і mLTE-U.

Динамічне налаштування ТХОР та періодів вимикання (наприклад, mLTE-U та CSAT-подібні підходи) у поєднанні з інформацією від моделей розпізнавання сигналу і RL/Q-learning дозволяє підлаштовувати часові вікна передач так, щоб забезпечити короткотривалу агрегацію LTE без довготривалого пригнічення Wi-Fi. На практиці комбінування CNN-класифікатора (впізнає співіснуючі передавання та приховані вузли) із Q-learning для вибору шаблону вимикання передавача показує кращу адаптацію в динамічному середовищі. Очікувану пропускну здатність LTE у слоті t на каналі c можна наближено моделювати як:

$$\mathbb{E}[T_{t,c}] = \alpha_{t,c} C_{t,c} (1 - p_{t,c}^{\text{coll}}),$$

де $C_{t,c}$ – фізична пропускну здатність, наприклад $B_c \log_2(1 + \text{SINR}_{t,c})$, а $p_{t,c}^{\text{coll}}$ – імовірність колізії або затримки, яка залежить від $\alpha_{t,c}$ та активності інтерферуючого передавача. Для простоти можна апроксимувати $p_{t,c}^{\text{coll}} \approx p_{t,c}^{\text{busy}}$ при малих α . Детектор (CNN) оцінює вікно сигналу $X_{t,c}$ і повертає апостеріорну ймовірність наявності активності та супутні ознаки, такі як оцінка числа активних Wi-Fi-вузлів $n_{t,c}$ та невпевненість $\sigma_{t,c}$.

Багатокористувацьке та багатоагентне навчання (Multi-Agent RL). Коли на одному просторі діють кілька операторів, корисно формулювати проблему як нерегульовану гру між агентами з моделями переваг, що враховують справедливість і глобальні обмеження ефірного часу. Розподілені RL-алгоритми із взаємним навчанням (MA-DDPG, Multi-Agent Deep Deterministic Policy Gradient – Багатоагентний глибокий детермінований градієнт стратегії) або підходи на основі границь рівноваги дозволяють досягати змішаних стратегій рівноваги Неша (Mixed-Strategy Nash Equilibrium – MSNE), зменшуючи потребу в централізованому обміні інформацією. Нехай у неліцензованому каналі діє множина агентів $I = \{1, \dots, N\}$ (SBS різних операторів). Динаміка описується стохастичною грою:

$$G = \langle I, S, \{A_i\}_{i \in I}, P, \{r_i\}_{i \in I}, \gamma \rangle,$$

де S – простір станів (оцінки завантаження, історія ефірного часу, довжина черги, SNR тощо), A_i – простір дій агента i (вибір каналу, чергування пауз/передавання α_i , патерн вимикання передавача), $P(s' | s, a)$ – перехідні ймовірності, r_i – індивідуальна винагорода, $\gamma \in (0, 1)$ – коефіцієнт дисконту. Сукупна дія $a = (a_1, \dots, a_N)$ визначає взаємний вплив на пропускну здатність та колізії. Очікувана пропускну здатність агента i визначається як:

$$\mathbb{E}[T_i] = \alpha_i C_i (1 - p_i^{\text{coll}}(\alpha, \lambda)),$$

де p_i^{coll} зростає зі збільшенням агрегованої інтенсивності інтерферуючих передавачів $\sum_{j \neq i} \alpha_j$. У статичному наближенні за один епізод кожен агент розв'язує:

$$\max_{\alpha_i \in [0,1]} u_i(\alpha_i, \alpha_{-i})$$

де α_i – профіль інших агентів. Рівновага Неша (Nash Equilibrium – NE) досягається при профілі α^* :

$$u_i(\alpha_i^*, \alpha_{-i}^*) \geq u_i(\alpha_i^*, \alpha_{-i}^*) \quad \forall \alpha_i.$$

Через стохастичність і часткову спостережуваність зазвичай досягаються змішані стратегії: кожен агент використовує розподіл $\pi_i(a_i|s)$. MARL-алгоритми, такі як градієнт стратегій, апроксимують такі π_i , що наближають NE, або корельовану рівновагу.

Розподілене навчання та приватність (Федеративне/передавальне навчання). Через обмеження приватності і трафіку контролю управляти централізовано великими обсягами RF-даних неефективно. Федеративне навчання дає змогу навчати спільні моделі розпізнавання спектра або політик доступу, залишаючи сирі I/Q дані на стороні базових станцій. Передавальне навчання дозволяє прискорити адаптацію моделей до нових середовищ (інше розташування AP, інший рівень шуму) за рахунок попереднього навчання на синтетичних або історичних датасетах в поєднанні з квантуванням і компактною архітектурою для Edge-розгортання. Задача цього підходу формалізується через набір базових станцій та пристроїв $K = \{1, \dots, K\}$, кожен з яких має локальний датасет D_k , наприклад I/Q-вікна, спектральні ознаки, локальні MAC-метрики з метою навчити глобальну модель w (наприклад, CNN-класифікатор або політику RL/NN) без централізації сирих даних. Типова федеративна ітерація складається з локального оновлення на підмножині клієнтів та агрегування їхніх оновлень на сервері. Класичний оптимізаційний вигляд:

$$\min_w F(w) = \sum_{k=1}^K \frac{n_k}{n} F_k(w), \quad F_k(w) = \mathbb{E}_{(x,y) \sim D_k} [l(w; x, y)],$$

де $n_k = |D_k|$, $n = \sum_k n_k$, l – локальна функція втрат. Один раунд навчання описується наступним чином: сервер має ваги w^t , вибирається підмножина клієнтів S^t , після чого кожен клієнт $k \in S^t$ виконує E епох локального SGD (Stochastic Gradient Descent – Стохастичний градієнтний спуск) з початковими вагами w^t та отримує w_k^{t+1} :

$$w^{t+1} = \sum_{k \in S^t} \frac{n_k}{\sum_{j \in S^t} n_j} w_k^{t+1}$$

Локальний крок клієнта (SGD), кожні E епох:

$$w = w - \eta \nabla l(w; x_b)$$

Online-адаптація, мета-навчання і робота при обмежених SNR. Щоб моделі виживали при змінних SNR і непередбачених каналних ефектах, потрібні механізми онлайн-навчання (оновлення ваг у польових умовах в реальному часі) і мета-навчання (Model-Agnostic Meta-Learning – MAML) для швидкої адаптації до нових каналів/пристроїв. Крім того, при низьких SNR корисно комбінувати статистичні особливості сигналу (ручні ознаки) з ознаками, витягнутими CNN, щоб підвищити стійкість класифікатора. Початково навчені CNN втрачають точність при поганому SNR, тому оновлення в реальному часі є обов'язковим елементом практичного розгортання. При наявності даних з мітками у польових умовах використовують інкрементальні оновлення:

$$\theta_{t+1} = \theta_t - \eta_t \nabla_{\theta} l(f_{\theta_t}(x_t, z_t), y_t)$$

де η' – мала швидкість навчання (гранична 10^{-5} - 10^{-4} або адаптивна 10^{-4} - 10^{-5}). Щоб запобігти катастрофічному забуванню, додається регуляризаційний терм від попередньої моделі:

$$L(\theta) = l_{task}(\theta) + \lambda_{reg} \|\theta - \theta_{prev}\|^2$$

Після навчання на попередньому домені з параметрами і оцінками важливості параметрів (інформації за Фішером), додатково додаються ваги при адаптації:

$$L(\theta) = l(\theta; D_{new}) + \frac{\lambda}{2} \sum_i F_i(\theta_i - \theta_i^*)^2$$

Оцінка F_i – емпірична інформація за Фішером:

$$F_i \approx \frac{1}{|D|} \sum_{(x,y) \in D} \left(\frac{\partial}{\partial \theta_i} \log p(y | x, \theta^*) \right)^2$$

Таблиця 1

Методи підвищення ефективності роботи LTE-U з використанням машинного навчання та CNN

Метод	Короткий опис	Вхідні дані/ознаки	Модель/підхід	Основні переваги
Класифікація та детекція передач	Ідентифікація типу сигналу (LTE, Wi-Fi та ін.) та режимів передавання в реальному часі	Сирі I/Q вибірки, спектральні представлення (FFT), короткі статистичні ознаки	CNN на I/Q або спектрограмах; легкі CNN для Edge-розгортання	Висока точність розпізнавання, дає сигнал для адаптивних рішень
Проактивне прогнозування завантаження	Прогноз майбутньої активності WLAN/навантаження для планування доступу	Історія ефірного часу, швидкість передачі, RSSI, час-серії трафіку	LSTM/RL-LSTM (поєднання прогнозу з оптимізацією)	Зниження колізій, краща пропускна здатність у середньостроковій перспективі
Навчання з підкріпленням для вибору каналу/підкадрів	Навчання політик вибору каналу, числа підкадрів, шаблонів вимикання передавача	Стан середовища: класифікатор спектру, винагорода (відношення пропускної здатності до рівноправності)	Q-learning/DQN	Адаптація до локального середовища без централізації
Адаптивне чергування передавання/пауз та вимикання передавача (на основі ML)	Динамічне налаштування періодів вимикання та TXOP під навантаження	Виміри ефірного часу, кількість активних Wi-Fi-вузлів, прогноз активності	Правила та Q-learning або стратегії вимикання	Мінімізує пригнічення Wi-Fi, підвищує ефективність LTE
Багатоагентні підходи та підходи на основі ігрової теорії	Розподілене співвідношення стратегій між кількома операторами	Локальні спостереження, часткові винагороди, сигнал від сусідів	Багатоагентне RL, градієнт стратегій, DDPG, механізми NE	Покращення глобальної взаємодії; зменшення потреби в централізації
Федеративне та передавальне навчання	Розподілене навчання моделей без передачі сирих I/Q даних	Локальні градієнти/моделі, метадані середовища	Федеративне усереднення, передавальне навчання з тонким налаштуванням	Приватність, менше backhaul-навантаження, швидка адаптація до нових локацій
Онлайн-адаптація та мета-навчання	Швидка адаптація моделей до нових умов і SNR	Нові польові дані, короткі епізоди виконання	Онлайн-навчання, MAML-подібні методи	Швидка реакція на зміну каналу; збереження продуктивності при поганому SNR
Оцінка ефективності та тестування	Комплексна валідація алгоритмів у синтетичних/реальних сценаріях	Сценарії з трафіком, прихованими вузлами, різними SNR	Симуляції та експерименти на COTS; A/B-тестування	Коректна кількісна оцінка пропускної здатності, затримки, рівноправності

Висновки

У роботі розглянуто проблему адаптивного доступу LTE у неліцензованому спектрі з урахуванням співіснування з Wi-Fi, регуляторних обмежень та практичних обмежень розгортання на Edge-пристроях. Залучення неліцензованого спектру є ключовим шляхом для розширення ємності мобільних мереж, але ефективне та «справедливе» співіснування з існуючими Wi-Fi мережами потребує комбінованого підходу – надійної детекції активності, короткострокового прогнозування і адаптивного контролю доступу до каналу. Поєднання легких CNN для класифікації/детекції ефірної активності, рекурентних моделей для прогнозування завантаження каналу та алгоритмів підкріплювального навчання для прийняття рішень дозволяє в реальному часі ухвалювати політики доступу (вибір каналу, TXOP, шаблони вимкнення), що краще узгоджують інтереси LTE і Wi-Fi у порівнянні зі статичними методами.

Формалізація винагороджувальної функції, що включає як метрику пропускну здатності LTE, так і штрафи за порушення критеріїв справедливості щодо Wi-Fi, дозволяє гнучко налаштовувати компроміс між збільшенням LTE-продуктивності та збереженням якості обслуговування суміжних систем. Варто враховувати, що система залежить від якості спостережень (шум, приховані вузли), від точності моделей прогнозування та від коректного вибору компонентів винагороди в RL. Крім того, реальна ефективність може змінюватися при значних відмінностях між симуляційними сценаріями та справжніми мережами.

Список використаної літератури:

1. License assisted access-WiFi coexistence with TXOP backoff for LTE in unlicensed band / S. Saadat et al. *China Communications*. 2017. Vol. 14, no. 3. P. 1–14. URL: <https://doi.org/10.1109/cc.2017.7897317>.
2. Alhulayil M., Lopez-Benitez M. LTE/Wi-Fi Coexistence in Unlicensed Bands Based on Dynamic Transmission Opportunity. 2020 IEEE Wireless Communications and Networking Conference Workshops (WCNCW), Seoul, Korea (South), 6–9 April 2020. 2020. URL: <https://doi.org/10.1109/wcncw48565.2020.9124747>.
3. Machine Learning Enabled Spectrum Sharing in Dense LTE-U/Wi-Fi Coexistence Scenarios / A. Dziedzic et al. *IEEE Open Journal of Vehicular Technology*. 2020. Vol. 1. P. 173–189. URL: <https://doi.org/10.1109/ojvt.2020.2981519>.
4. An Analytical Study Of Cellular Networks LTE-U and Wi-Fi in 5G Environment. *Lahore Garrison University Research Journal of Computer Science and Information Technology*. 2024. P. 17–31. URL: <https://doi.org/10.54692/lgurjcsit.2024.083503>.
5. Ahmad O., Farooq B. Auxiliary-LSTM based floor-level occupancy prediction using Wi-Fi access point logs. *Journal of Smart Cities and Society*. 2022. Vol. 1, no. 3. P. 195–211. URL: <https://doi.org/10.3233/scs-220012>.
6. A Q-Learning Scheme for Fair Coexistence Between LTE and Wi-Fi in Unlicensed Spectrum / V. Maglogiannis et al. *IEEE Access*. 2018. Vol. 6. P. 27278–27293. URL: <https://doi.org/10.1109/access.2018.2829492>.
7. Dynamic Spectrum Coexistence of NR-V2X and Wi-Fi 6E using Deep Reinforcement Learning / K. D. Shah et al. *IEEE Open Journal of the Computer Society*. 2025. P. 1–12. URL: <https://doi.org/10.1109/ojcs.2025.3586664>.
8. Wi-Fi Coexistence with Duty Cycled LTE-U / Y. Pang et al. *Wireless Communications and Mobile Computing*. 2017. Vol. 2017. P. 1–10. URL: <https://doi.org/10.1155/2017/6486380>.
9. RL-Based Energy-Efficient Data Transmission Over Hybrid BLE/LTE/Wi-Fi/LoRa UAV-Assisted Wireless Network / W. A. Nelson et al. *IEEE/ACM Transactions on Networking*. 2023. P. 1–16. URL: <https://doi.org/10.1109/tnet.2023.3332296>.
10. He L., Cheng H., Zhang Y. Centralized and Decentralized Event-Triggered Nash Equilibrium-Seeking Strategies for Heterogeneous Multi-Agent Systems. *Mathematics*. 2025. Vol. 13, no. 3. P. 419. URL: <https://doi.org/10.3390/math13030419>.

11. Ali R., Almagrabi A. O. Beyond Wi-Fi 7: Enhanced Decentralized Wireless Local Area Networks with Federated Reinforcement Learning. *Computers, Materials & Continua*. 2025. P. 1–10. URL: <https://doi.org/10.32604/cmc.2025.070224>.
12. Reinforcement Learning for Efficient and Fair Coexistence Between LTE-LAA and Wi-Fi / M. Han et al. *IEEE Transactions on Vehicular Technology*. 2020. Vol. 69, no. 8. P. 8764–8776. URL: <https://doi.org/10.1109/tvt.2020.2994525>.
13. Basnet M. B. Predicting Channel Quality Indicator (CQI) in LTE Using Ensemble Learning Approaches. *Divya Gyan Journal of Business and Computing*. 2026. Vol. 1, no. 1. P. 55–72. URL: <https://doi.org/10.3126/dgjbc.v1i1.91087>.
14. Muthirayan D., Kalathil D., Khargonekar P. P. Meta-Learning Online Control for Linear Dynamical Systems. *IEEE Transactions on Automatic Control*. 2025. P. 1–7. URL: <https://doi.org/10.1109/tac.2025.3536839>.

Автори статті

Швець Дмитро – аспірант, Державний університет інформаційно-комунікаційних технологій, Київ, Україна.

ORCID: 0009-0007-9059-7064

Трейтяк В'ячеслав – кандидат технічних наук, доцент, Державний університет інформаційно-комунікаційних технологій, Київ, Україна.

ORCID: 0000-0002-9275-3354

Authors of the article

Shvets Dmytro – postgraduate, State University of Information and Communication Technologies, Kyiv, Ukraine.

ORCID: 0009-0007-9059-7064

Treitiak Viacheslav – Candidate of Sciences (technical), Associate Professor, State University of Information and Communication Technologies, Kyiv, Ukraine.

ORCID: 0000-0002-9275-3354

Надійшла до редакції: 26.02.2026

Прийнята до друку: 13.03.2026

Опубліковано: 25.05.2026

© 2026 Швець Д.М., Трейтяк В.В.

Цей матеріал ліцензовано за умовами CC BY 4.0. <https://creativecommons.org/licenses/by/4.0>